基于全卷积网络的鳞翅目标本图像前背景自动分割方法研究

竺乐庆[1,*], 马梦园[1], 张 真[2], 孟昭军[3], 吴 伟[4], 任利利[5], 高翠青[6], 南小宁[7]

(1. 浙江工商大学计算机与信息工程学院, 杭州 310018;
2. 中国林业科学研究院森林生态与保护研究所, 国家林业局森林保护学重点实验室, 北京 100091;
3. 东北林业大学林学院, 哈尔滨 150040; 4. 西南林业大学保护生物学学院, 昆明 650224;
5. 北京林业大学林学院, 北京 100083; 6. 南京林业大学林学院, 南京 210037;
7. 西北农林科技大学林学院, 陕西杨凌 712100)

摘要:【目的】本研究旨在探索使用计算机视觉技术实现对鳞翅目标本图像的前背景分割方法。【方法】首先对用于训练和测试的昆虫标本图像去除背景,获得昆虫图像的前背景分割参考标准,对过大的昆虫图像进行缩小处理;其次对训练集图像采用旋转、平移、缩放等方法进行数据增强,剪切出中心区域作为有效图像。求取所有训练样本的均值图像,并从所有输入中减去该均值图像。测试用图像只做归一化但不进行数据增强。微调全卷积神经网络,重点调整结构产生变化的卷积层和反卷积层的参数,用前述训练数据集训练直至收敛。对于待分割图像,只要将图像归一化后输入到训练好的全卷积网络,网络将输出前背景分割结果。【结果】该方法在包含823个样本的测试集中进行了测试,取得的mIoU(mean Intersection over Union)达94.96%,而且分割的视觉效果已经非常接近于人工分割的结果。【结论】实验结果证明通过训练全卷积神经网络可以有效实现鳞翅目标本图像的前背景自动分割。

关键词: 鳞翅目; 图像处理; 前背景分割; 深度学习; 全卷积神经网络

中图分类号: Q969.42 **文献标识码:** A **文章编号:** 0454-6296(2018)02-0255-08

Foreground-background segmentation of lepidopteran specimen images based on fully convolutional networks

ZHU Le-Qing[1,*], MA Meng-Yuan[1], ZHANG Zhen[2], MENG Zhao-Jun[3], WU Wei[4], REN Li-Li[5], GAO Cui-Qing[6], NAN Xiao-Ning[7] (1. School of Computer Science and Information Engineering, Zhejiang Gongshang University, Hangzhou 310018, China; 2. Key Laboratory of Forest Protection of State Forestry Administration, Research Institute of Forest Ecology, Environment and Protection, Chinese Academy of Forestry Sciences, Beijing 100091, China; 3. School of Forestry, Northeast Forestry University, Harbin 150040, China; 4. Faculty of Conservation Biology, Southwest Forestry University, Kunming 650224, China; 5. School of Forestry, Beijing Forestry University, Beijing 100083, China; 6. School of Forestry, Nanjing Forestry University, Nanjing 210037, China; 7. College of Forestry, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract:【Aim】This study aims to realize the automatic foreground-background segmentation of lepidopteran specimen images by exploring the state-of-art computer vision technology.【Methods】First, the background is manually removed to form the ground truth of training set and testing set, and those

基金项目: 国家林业局推广项目[森林昆虫自动识别技术-2014(10)]

作者简介: 竺乐庆, 女, 1972 年生, 博士, 副教授, 主要研究方向为图像处理、模式识别与嵌入式系统, E-mail: zhuleqing@zjgsu.edu.cn
* 通讯作者 Corresponding author, E-mail: zhuleqing@zjgsu.edu.cn

收稿日期 Received: 2017-07-30; 接受日期 Accepted: 2017-11-21

images that are too large are resized to smaller ones. Then, the training set is enhanced by rotation, translation, scaling, *etc.*, and their central areas are cropped as valid input and target images. Afterwards, the mean image of all the training samples is calculated and subtracted from all input images. Testing images are simply normalized but not enhanced. Fully convolutional networks (FCNs) are fine-tuned with training set until they converge. The parameter adjustment on later convolutional layers and de-convolutional layers is emphasized since their structures are different from those of original immigrated FCNs. When one given insect image is fed into the trained FCN after normalization, the segmentation result will be given. 【Results】The proposed method was evaluated with the testing set including 823 samples, and the final mIoU (mean Intersection over Union) was as high as 94.96%. The visual effect of segmentation results given by FCN was much close to the manually produced results. 【Conclusion】 The experimental results prove that the foreground-background of lepidopteran specimen images can be segmented efficiently by the trained FCN.

Key words: Lepidoptera; image processing; foreground-background segmentation; deep learning; fully convolutional network (FCN)

鳞翅目是昆虫纲的第二大目,在全世界已知的就有 20 万种之多,多数鳞翅目昆虫幼虫取食植物叶肉、或蛀食树干、树皮、树根,为农业上的主要害虫之一,也有少数种类如蚕、柞蚕等是有益于人类的经济昆虫。昆虫学的研究、害虫防治、生物防治和植物检疫都离不开对昆虫种类的准确鉴定。鳞翅目昆虫的口器、翅脉、触角、翅面鳞片的颜色纹理特征、甚至昆虫的生殖器官结构等均是它们分类的重要依据。然而对昆虫种类的人工鉴定是一项耗时、代价高昂且必须由经过长期培训的专业人员才能完成的工作。Weeks 等(1999)在 20 世纪 90 年代便推出了基于昆虫形态学和分子数据的昆虫自动种类鉴定系统 DAISY (digital automated identification system)。在昆虫图像自动种类识别过程中,对昆虫主体的有效分割,可以避免背景中所包含的颜色纹理等信息对分类结果产生干扰。在国外,Patil 和 Hegadi (2009) 提出了一种基于 sobel 边缘检测的棉花害虫图像分割方法;Sangari 等(2016)提出了基于蚁群算法(ant colony optimization, ACO)和改进的粒子群优化算法(particle swarm optimization, PSO)的昆虫图像分割算法,用于分割图像中的粉虱、蚜虫等微小昆虫;Mele(2013)提出基于全局阈值与局部种子区域生长法相结合的昆虫图像分割方法,但仅适用于背景颜色固定且均匀单一的图像。在国内,针对昆虫彩色图像的前背景自动分割方法有刘晓静等(2008)提出的基于静态图像压缩标准分割算法、黄世国等(2008)提出的快速几何可变形彩色图像分割方法、程小梅等(2009)通过最大期望算法迭代出混合高斯模型的图像分割方法、兰红和王璇(2014)提出的结合过渡区的多元线性回归昆虫图像分割方法等。

近年来,计算机软硬件技术发展迅速,更快、更高效的硬件满足了深度学习对运算能力的需求,促使“复杂”的深度学习不断取得突破。深度卷积神经网络(deep convolutional neural network, DNN)将特征提取与分类自然地融合从而得到一个端到端的分类框架(Krizhevsky *et al.*, 2012)。其权值共享的网络结构不仅极大地降低了模型复杂度,而且模拟了基于神经元反应的视觉系统,有较强的模型泛化能力。Shelhamer 等(2017)将 AlexNet (Krizhevsky *et al.*, 2012) 和 VGG16 (Simonyan and Zisserman, 2015)等提出的分类网络改成了全卷积网络并将分类网络的学习参数迁移到语义分割任务中。本文参考该语义分割全卷积网络结构,对深度学习框架应用于昆虫图像前背景分割进行研究,将前背景分割转化为像素级的二分类问题,通过训练和学习,深度卷积神经网络将能很好地根据输入的 RGB (red green blue)图像将所有像素划分为前景和背景两类,最终完成前背景分割的任务。

1 材料与方法

1.1 鳞翅目昆虫图像采集与准备

本文所用到的昆虫图像均为鳞翅目标本图像,由中国林业科学研究院森林生态与保护研究所、东北林业大学林学院、西南林业大学保护生物学学院、北京林业大学林学院、南京林业大学林学院、西北农林科技大学林学院等单位联合采集、制作并拍摄,一共包含 64 类合计 3 823 个鳞翅目标本图像样本。

图 1 为该数据集中的部分原始图像样本。从图 1 可知该数据集中背景的颜色包括红、蓝、米、灰蓝、灰绿、绿等 6 种不同色调(图 1：A－F)，大部分是带标本标签的纯色背景(图 1：A－E)，少部分不带标本标签(图 1：F)，少量样本背景包括两种以上颜色(图 1：G，H)，还有少量背景有明显的阴影(图 1：F)或前背景颜色非常接近的样本(图 1：C)。所有的样本都用手动方式去除了背景并统一把背景填充为黑色(如图 2：B)，并自动生成二值蒙板(图 2：C)作为训练卷积神经网络(convolutional neural network，CNN)的目标图像。为了方便输入到卷积神经网络中进行训练和测试，我们将所有的昆虫图像样本的大小进行了归一化处理：首先对图 2(C)所示的前景求取最小包围盒(图 2：D)，将该包围盒的长边 l 与 224 进行比较，若 $l>224$，则按比例因子 $s=224/l$ 对原图和前景蒙板图进行等比例缩小，否则不变，然后以包围盒为中心，剪切出原始彩色图像和目标前背景二值图像中 300×300 大小的区域(图 3)。在整个数据集中随机选择 3 000 个样本作为训练集，剩余的 823 个样本作为测试集。



图 1　不同背景鳞翅目标本图像示例

Fig. 1　Samples of lepidopteran specimen images with different background colors

A：红色 Red；B：蓝色 Blue；C：灰绿 Grey-green；D：灰蓝 Grey-blue；E：绿色 Green；F：米色 Beige；G，H：红蓝两色 Red and blue.

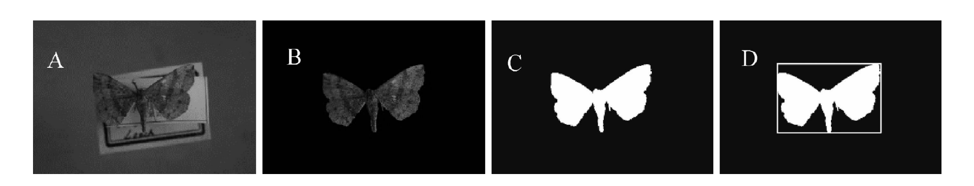


图 2　数据预处理示例

Fig. 2　Demonstration for data preprocessing

A：原图 Original image；B：去除背景图像 Image with background removed；C：前景蒙板 Foreground mask；D：最小包围盒 Minimum bounding box of foreground.

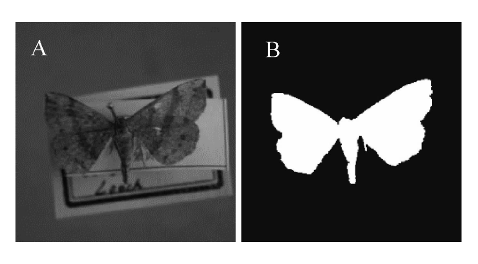


图 3　归一化后的原图和目标图

Fig. 3　Normalized image and target

A：原图 Origin image；B：目标图 Target image.

1.2　训练样本的数据增强

由于 CNN 有上千万的参数，即使对网络进行微调，也需要足够数量的训练样本以防止产生过拟合现象，本文中总的训练样本只有 3 000 个，需要通过数据增强的方式获得足够数量的训练样本，数据增强方式如下：

A. 平移：将输入和目标图像向左上、右上、左下、右下 4 个方向平移 8 个像素，加上未平移原图，裁剪出中心的 256×256 区域保存后每图像得到 5 个不同副本；

B. 旋转：将输入和目标图像旋转 $r\in[-5°, 5°]$，裁剪出中心的 256×256 区域保存；

C. 缩放：将输入和目标图像按比例因子 $s\in[0.85, 1]$进行缩小，裁剪出中心的 256×256 区域保存；

D. 颜色抖动:将输入图像的 RGB 颜色值统一用因子 $c \in [0.8, 1.2]$ 相乘,并将超过 255 的值设置为 255 以避免溢出失真,裁剪出输入和目标图像中心的 256 ×256 区域保存;

E. 水平镜像:将 A 中的未平移副本、B、C、D 的输入和目标以 50% 的概率进行水平镜像。

上述数据增强操作 A, B, C 和 D 4 个步骤是同时混合进行的,经过数据增强后训练集扩充为 30 000个 256 ×256 大小的样本,对所有训练样本的输入图像求平均,即将所有图像对应通道对应位置的像素值求和后除以图像总数,得到 256 ×256 大小的三通道均值图像,并从所有训练样本的输入中减去对应像素位置的均值。为了使网络在训练过程中能逐渐收敛,避免损失大起大落,需要保证在每一批训练数据中各类的样本均衡分布,因此对数据进一步作了置乱处理形成最后的训练集。

对于测试数据,则不需要数据增强,我们只是简单地将测试数据的输入和目标裁剪出中心的 256 × 256 区域,并从输入图像减去训练样本均值。

1.3 FCN 网络结构

本文所使用的 FCN 是对 Shelhamer 等(2017)提出的语义分割全卷积网络的微调,Shelhamer 等将 AlexNet (Krizhevsky *et al*., 2012) 和 VGG16 (Visual Geometry Group 16-layer) (Simonyan and Zisserman, 2015) 等 CNN 中的全连接层全部用卷积层代替,这样做的好处是:一方面可以降低网络参数的数量,因为卷积核在同一层中可以共享;另一方面,全卷积网络对输入图像的大小不敏感,不像传统的 CNN 只能限制于处理同样大小的输入,如果输入大小产生变化,则需要重新训练网络。

本文所微调的第一个网络为 FCN-AlexNet,网络结构如图 4 所示。从图 4 知该网络的前几层结构与 AlexNet 完全相同,但其中的全连接层用卷积层替代了,从 Conv1 到 Conv7 的网络参数与 Shelhamer 等提出的 FCN-AlexNet 完全相同,参数值可从预训练的 FCN-AlexNet 迁移过来;Conv8 及随后的反卷积层参数则从头开始训练,设置相对大的学习率。Conv8 之后的反卷积层卷积核大小为 63,步长 32,可将 9 ×9 的输入上采样至 319 ×319,然后通过 crop 层根据原图尺寸和偏移量参数裁剪至与原图同样大小后输出。本文所实现的 FCN 是基于 CAFFE (convolutional architecture for fast feature embedding) 框架 (Jia *et al*., 2014) 的。开始时,从 Conv1 到 Conv7 的学习率均设置为 0.001,第 8 个卷积层权值的学习率为 0.1,偏移量的学习率为 0.2,反卷积层 (Deconv) 学习率为 0.1,此后学习率按每 1 000 轮迭代调整为上一轮的 0.7,训练数据的 batch_size 为 32,测试数据的 batch_size 为 16。网络最终输出的两个通道值是每像素属于背景和前景的概率,将各像素归类为概率大的那一类即可得到前背景分割结果。训练时损失函数计算采用 softmaxWithLoss (Bishop, 2006),其计算公式如下:

$$loss = \sum_{-i=1}^{n} \log \frac{e^{z_{ki}}}{e^{z_{0i}} + e^{z_{1i}}} \quad (1)$$

其中 n 为输出结果的总像素个数,而 k 取决于目标图像中该像素的归属,属于前景取 1,属于背景则取 0。训练进行了 10 000 轮迭代后网络收敛,训练结束。

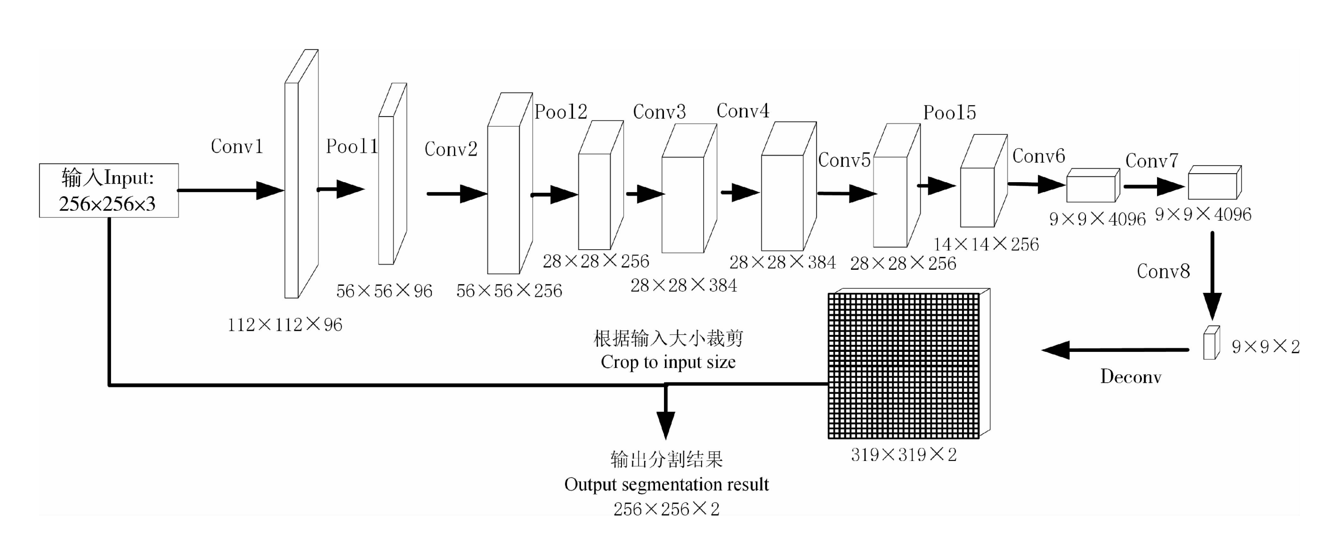


图 4 本研究微调的 FCN-AlexNet 网络结构(Shelhamer *et al*., 2017)

Fig. 4 The network structure of FCN-AlexNet (Shelhamer *et al*., 2017) fine-tuned in this study

本文所微调的另一个 FCN 是基于 VGG16 的，网络结构如图 5 所示。图中从 Conv14 到 Conv16 3 个卷积层在原生的 VGG16 网络中是全连接层，此处改为卷积层，从而起到减少参数数量和对输入图像大小不敏感的作用。该网络除了从最后的输出得到分割结果外，还从 Conv7 及 Conv10 之后分别引出分支来进一步细化前背景分割的边缘细节。卷积神经网络的低层输出包含局部细节特征，而高层的感受野更大，反映的是全局特征，低层特征的引入将使最终的输出细节更丰富。整个网络从 Conv1 到 Conv15 这 15 个卷积层的整体结构与 Shelhamer 等(2017)提出的基于 VGG16 的语义分割全卷积网络相同，这部分网络参数可以从 Shelhamer 等提出的 FCN 迁移过来，但 Conv16，Conv B1，Conv B2 以及所有的反卷积层的参数则要从头训练，并设置较大的学习率。训练和测试数据的 batch_size 均为 4，基础学习率为 0.001，学习率按每 8 000 轮迭代调整为上一轮的 0.7，从 Conv1 到 Conv15 的学习率均设置为 0.01，Conv16，Conv B1 和 Conv B2 卷积层和反卷积层的学习率为 1，偏移量的学习率为 2。网络最终输出的两个通道值是每像素属于背景和前景的概率，将各像素归类为概率大的那一类即可得到前背景分割结果。训练进行 80 000 轮迭代网络趋于收敛后结束。

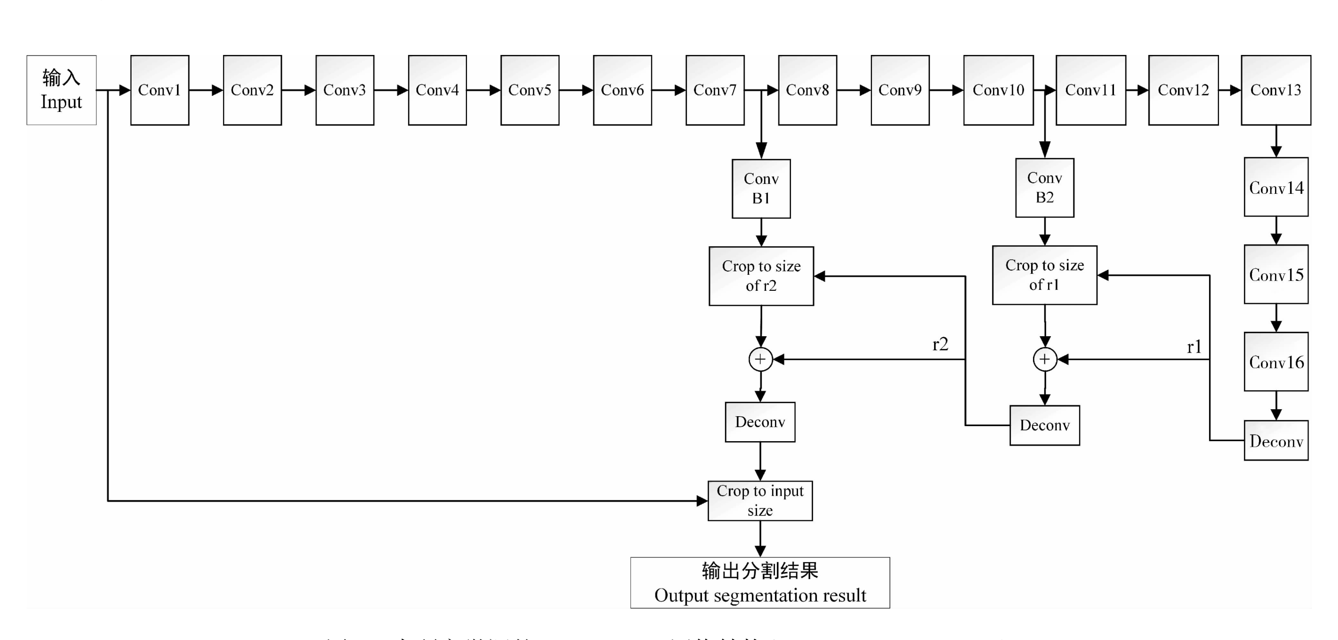


图 5　本研究微调的 FCN-VGG16 网络结构(Shelhamer *et al.*, 2017)

Fig. 5　The network structure of FCN-VGG16 (Shelhamer *et al.*, 2017) fine-tuned in this study

1.4　分割结果的评价标准

我们用 IoU (Intersection over Union)来衡量分割结果的优劣，IoU 的计算公式如下：

$$O[R,R'] = \left|\frac{R' \cap R}{R' \cup R}\right| = \frac{TP}{TP+FP+FN} \quad (2)$$

如对前景像素而言，R 为参考标准(ground truth)的前景区域，R' 为预测的前景区域，则 IoU 是指在两区域中均出现的像素个数与两区域合并后的区域总像素个数的比值，也即真阳(true positive，TP)(实际为前景也预测为前景)像素个数与真阳、假阳(false positive，FP)(实际为背景而预测为前景)和假阴(false negative，FN)(实际为前景而预测为背景)像素和的比值，背景的 IoU 也可用类似方法计算，前背景的 IoU 平均后得到 mIoU (mean Intersection over Union)。

2　结果

2.1　分割效果的定量评价

上述方法在装有 Ubuntu 系统的 PC 机上实现，CPU 为 Intel Core i7-7700 2.8 GHz，内存为 16 GB，GPU 为 NVIDIA GeForce GTX 1060，显存为 6 GB。FCN 用 CAFFE 框架实现，训练和测试均使用 GPU 来提高性能。我们创建的图像库中包含 64 类鳞翅目昆虫，每类昆虫有 20～285 个不同图像样本，合计 3 823 个样本。作为比较，我们也将 GrabCut 算法(Rother *et al.*, 2004)的前背景分割结果进行了统计和展示，使用 GrabCut 算法时，需要指定一个矩形

框，使得前景像素完全处于框内，而框外像素则完全是背景，我们把这个框默认设置成输入图像中心 224×224 的区域，因为我们在数据准备时，已经把前景的区域通过缩放限制在 224×224 大小的中心区域。

表 1 是本文所采用的 FCN-AlexNet，FCN-VGG16 及 GrabCut 在测试集上进行前背景分割的结果统计与比较。从表中数据可知，对于鳞翅目昆虫前背景分割任务而言，全卷积网络的分割效果要远优于 GrabCut，这一结果还是容易被理解和接受的，因为 GrabCut 是一种广谱的前背景分割算法，而全卷积网络则专门针对鳞翅目昆虫标本图像进行了参数调优，使各项参数特别适合于鳞翅目昆虫标本图像的前背景分割。表 1 同时给出了 FCN 在 3 000 个训练样本上和 823 个测试样本上的分割结果比较，训练集上的 IoU 略高于训练集，既然网络是基于训练集数据进行参数调优的，分割结果优于测试集也是意料之中的，但测试集上的 IoU 已经非常接近训练集，说明网络已经获得了比较理想的泛化能力。此外，我们也从表 1 数据可知，FCN-VGG16 的分割效果要优于 FCN-AlexNet，这是因为 FCN-VGG16 的网络更深（卷积层多达 18 层，FCN-AlexNet 只有 8 层），模型更复杂（参数多达 134 兆，FCN-AlexNet 为 57 兆），并且 FCN-VGG16 还从低层特征引入了多尺度信息，使得最后的分割结果细节更丰富。当然复杂模型的代价也是显著的，同样训练数据跑 10 趟的训练时间 FCN-AlexNet 只需 2.6 h，FCN-VGG16 则需要 16 h，而对单张图像的一次分割在 GPU 上 FCN-AlexNet 只需 15 ms 左右，而 FCN-VGG16 需要 57 ms 左右。表中也给出了分割单张图像如果完全用 CPU 实现，FCN-AlexNet 需要 1.032 s，FCN-VGG16 需要 6.9 s，GrabCut 则需要 0.533 s（GrabCut 不是本文的研究目标，因此未实现 GPU 版本），由此可见，在深度学习框架中，GPU 扮演着很重要的角色，GPU 使得深度学习网络的训练和使用性能提高成百上千倍，从而也促使深度学习实践和应用发展迅猛。

表 2 给出了用 FCN-VGG16 做分割时按不同背景颜色和复杂度所做的分类统计结果，从表 2 可知，红、绿、蓝、灰蓝、灰绿这几种颜色的 mIoU 大致相当，分布在平均值附近，而米色背景的 mIoU 明显低于其他颜色，这是因为米色背景的训练样本总共只有 30 多个，其他颜色都至少有几百个，在整个训练集中数量明显低于其他背景颜色样本，而且米色背景的样本部分带阴影，因为网络无法对这些情况进行充分学习导致分割性能低于其他背景颜色的样本；同时，从表 2 可知，虽然带标签的 mIoU 略低于无标签的，样本的背景带标签、不带标签、多色（指背景非纯色）统计得到的 mIoU 大致相当，说明只要训练样本足够丰富，网络还是能够学会在相对复杂的背景中分辨出前景主体。

表 1 FCN-AlexNet，FCN-VGG16 及 GrabCut 的结构性能比较

Table 1 Structure and performance comparison among FCN-AlexNet，FCN-VGG16 and GrabCut

		前景 IoU（%）Foreground IoU	mIoU（%）	单次分割时间 Time to segment one image（ms）		训练时间（h）Training time
				GPU	CPU	
FCN-AlexNet	训练集 Training set	89.261	93.132	15	1 032	2.6
	测试集 Testing set	87.907	92.187			
FCN-VGG16	训练集 Training set	92.229	95.050	57	6 900	16
	测试集 Testing set	92.134	94.955			
GrabCut	71.445	80.246	-	533	-	

IoU：Intersection over Union；mIoU：Mean Intersection over Union.

表 2 按背景颜色和复杂度分类统计结果

Table 2 Statistics according to different background colors and complexities

背景颜色或复杂度 Background color or complexity	绿色 Green	蓝色 Blue	红色 Red	灰蓝 Grey-blue	灰绿 Grey-green	米色 Beige	带标签 With label	无标签 Without label	多色 Multi-colors
mIoU（%）	94.01	95.23	95.04	95.15	95.25	91.36	94.79	95.63	95.41

2.2　分割方法的定性分析

图 6 给出了测试集中 4 个样本 3 种前背景分割结果的定性比较，图中，第 1 列为输入的 RGB 彩色图像，第 2 列为人工去除背景后的参考标准图像，第 3 列为根据 FCN-AlexNet 预测结果去除背景后的图像，第 4 列为根据 FCN-VGG16 预测结果去除背景后的图像，第 5 列为用 GrabCut 算法去除背景后的图像；图 6（A）和（B）是对大小为 256 × 256 的图像处理结果，图 6（C）是对 227 × 227 大小图像的处理结果，图 6（D）是对 224 × 224 大小图像的处理结果。综上所述，使用 FCN-VGG16 能很好地分割出鳞翅目标本图像的前背景区域，分割的结果甚至逼近人工操作结果，在 GPU 上 50 ms 的处理速度也非常让人满意；如果要求不高，用 FCN-AlexNet 也能大致把产生干扰的背景去除，处理速度要高于 FCN-VGG16。从图 6（C，D）也可知，网络对输入图像大小的变化不敏感。



图 6　鳞翅目标本图像前背景分割结果的定性比较

Fig. 6　Qualitative comparison of foreground-background segmentation results for lepidopteran specimen images

从左到右依次为原图，人工分割结果，FCN-AlexNet 的结果，FCN-VGG16 的结果，GrabCut 算法的结果。From left to right are the original image and the results of manual segmentation, FCN-AlexNet, FCN-VGG16 and GrabCut algorithm, respectively. 图像大小 Image size：A，B：256 × 256；C：227 × 227；D：224 × 224.

3　讨论与结论

本文提出了一种全新的鳞翅目标本图像的前背景分割方法，从而可以自动去除所拍摄的鳞翅目昆虫标本图像中的背景，消除背景对昆虫图像的识别或分析所造成的干扰。本文通过微调全卷积网络 FCN-AlexNet 和 FCN-VGG16 实现对昆虫图像的前背景分割，用 3 000 个样本通过数据增强形成包含 30 000 个样本的训练集，用 823 个测试样本进行评估，并与 GrabCut 算法进行了对比。评估结果表明，微调得到的 FCN-VGG16 在本文中的前背景分割任务取得的精度最佳，FCN-AlexNet 的分割精度略低但时间性能较佳，而 GrabCut 虽然适用面广，但不能很好地去除背景中的干扰因素，在本文数据集上的分割结果较为粗糙。本文中所取得的成果，结合笔者前几年在昆虫种类自动识别上所做工作，可以使鳞翅目昆虫的种类的识别整个流程真正实现全自

动,把人类从繁杂的手工操作中解放出来。下一步的研究方向是把昆虫的前背景分割与种类鉴定整合成一个大的 CNN 网络,从原始拍摄图像通过一个端到端的系统实现识别而识别精度不产生明显下降。

参考文献(References)

Bishop CM, 2006. Pattern Recognition and Machine Learning. Springer, Singapore. 46 - 66.

Cheng XM, Geng GH, Zhou MQ, Huang SG, 2009. Applying expectation-maximization in insect image segmentation using multi-features. *Comput. Appl. Soft.*, 26(2): 20 - 22. [程小梅, 耿国华, 周明全, 黄世国, 2009. 基于多特征的 EM 算法在昆虫图像分割中的应用. 计算机应用与软件, 26(2): 20 - 22]

Huang SG, Zhou MQ, Geng GH, 2008. Fast geometry deformable insect's color image segmentation algorithm. *Comput. Appl.*, 28(12): 3144 - 3146. [黄世国, 周明全, 耿国华, 2008. 快速几何可变形彩色昆虫图像分割算法. 计算机应用, 28(12): 3144 - 3146]

Jia YQ, Shelhamer E, Donahue J, Karayev S, Long J, Girshick R, Guadarrama S, Darrell T, 2014. Caffe: convolutional architecture for fast feature embedding. In: Proceedings of the 22nd ACM International Conference on Multimedia, Nov. 3 - 7, 2014, Orlando, Florida, USA. 675 - 678.

Krizhevsky A, Sutskever I, Hinton G, 2012. ImageNet classification with deep convolutional neural networks. In: Proceedings of the 25th International Conference on Neural Information Processing Systems, Dec. 3 - 6, 2012, Lake Tahoe, Nevada, USA. 1: 1097 - 1105.

Lan H, Wang X, 2014. Insect image segmentation algorithm based on multiple linear regression and transition region. *Comput. Sci.*, 41(5): 315 - 318. [兰红, 王璇, 2014. 结合过渡区的多元线性回归昆虫图像分割方法. 计算机科学, 41(5): 315 - 318]

Liu XJ, Geng GH, Zhou MQ, Huo QS, 2008. A natural insects color image segmentation algorithm. *Comput. Appl. Soft.*, 25(11): 37 - 38. [刘晓静, 耿国华, 周明全, 霍青松, 2008. 一种基于复杂背景下的昆虫彩色图像分割方法. 计算机应用与软件, 25(11): 37 - 38]

Mele K, 2013. Insect soup challenge: segmentation, counting, and simple classification. In: Proceedings of the 2013 IEEE International Conference on Computer Vision Workshops, Dec. 2 - 8, 2013, Sydney, NSW, Australia. 168 - 173.

Patil R, Hegadi SR, 2009. Segmentation of cotton insects and pests using image processing. In: Proceeding of National Conference on Current Trends in Advanced Computing and e-Learning, Feb. 2009, Baramathi, India. 96 - 98.

Rother C, Kolmogorov V, Blake A, 2004. "GrabCut": interactive foreground extraction using iterated graph cuts. *ACM Trans. Graph.*, 23(3): 309 - 314.

Sangari AS, Saraswady D, Sasikumar G, 2016. Pest image segmentation using swarm intelligence in agricultural ecosystem. *IIOAB J.*, 7(Supp. 1): 326 - 331.

Shelhamer E, Long J, Darrell T, 2017. Fully convolutional networks for semantic segmentation. *IEEE Trans. Pattern Anal. Mach. Intell.*, 39(4): 640 - 649.

Simonyan K, Zisserman A, 2015. Very deep convolutional networks for large-scale image recognition. Published as a conference paper at ICLR 2015. 1 - 14.

Weeks PJD, O'Neill MA, Gaston KJ, Gauld ID, 1999. Automating insect identification: exploring the limitations of a prototype system. *J. Appl. Entomol.*, 123: 1 - 8.

(责任编辑: 赵利辉)